

FILOZOFSKI FAKULTET SVEUČILIŠTA U ZAGREBU

ODSJEK ZA INFORMACIJSKE I KOMUNIKACIJSKE

ZNANOSTI

AK. GODINA 2013./2014.

Softver za prepoznavanje lica

Diplomski rad

Lucija Urek

Mentor: prof. dr. sc. Hrvoje Stančić

Neposredni voditelj: dr. sc. Vjera Lopina

Zagreb, svibanj 2014.

SADRŽAJ:

1. UVOD:.....	6
2. POVIJEST	8
3. PROBLEMATIKA PREPOZNAVANJA LICA POMOĆU RAČUNALA.....	8
4. PREPOZNAVANJE LICA KOD LJUDI	12
4.1. Prepoznavanje kao funkcija dostupnih prostornih rezolucija	13
4.2. Prirodnost procesiranja: Dio po dio ili u cjelini	14
4.3. Pigmentacija, oblik, pokret.....	16
4.4. Razvojno napredovanje	21
5. PREPOZNAVANJE LICA KROZ STARENJE	23
6. ALGORITAM VIOLA – JONES	25
7. 3D MODELI	30
8. PREPOZNAVANJE LICA PREKO VIDEA	32
8.1.Primjer	33
9. UPORABA.....	34
9.1. Državna sigurnost.....	34
9.2. Komercijalna uporaba	35
10. BAZA PODATAKA	36
11. USPOREDBA S OSTALIM SUSTAVIMA	38
12. ZAKLJUČAK.....	39
13. LITERATURA	41

Sažetak

Tema ovoga rada odnosi se na problem pronalaženja učinkovitog softvera za prepoznavanje lica računalom i algoritma za takav softver. On se temelji na fotografijama lica osoba koje pretvara u predložak i uspoređuje fotografiju s bazom podataka raznih fotografija lica, tražeći podudaranje. Prvi korak kod bilo kojeg sustava za prepoznavanje lica je detekcija lica (eng. *face detection*), slijedi praćenje (eng. *face tracking*) i prepoznavanje lica sustavom (eng. *face recognition*). Pojasnit će se kako različiti uvjeti dobivanja slike ljudskih lica bitno utječu na identifikaciju, jer prolaze kroz mnoge promjene pa je u posljednjih 20 godina pronalaženje učinkovitih softvera izazov za znanstvenike iz različitih područja znanosti. Jedini sličan i trenutno najbolji sustav koji služi kao polazište svim znanstvenim istraživanjima je ljudska sposobnost prepoznavanja ljudi tj. ljudski mozak i oči. Osnovno polazište za izradu algoritma softvera za prepoznavanje lica je prepoznavanje lica putem fotografije ili video-zapisa, a problem dizajna algoritma koji uzima u obzir sve uvjete u kojima je lice snimljeno i sve promjene koje su se na njemu dogodile starenjem, načinom života ili prikrivanjem, područje je interesa u radu. Prikazat će se jedan od najpopularnijih algoritama (Viola – Jones), ali i uporaba softvera u različite svrhe te usporedba s ostalim sustavima.

Ključne riječi: *softver za prepoznavanje lica, detekcija lica, praćenje lica sustavom, prepoznavanje lica sustavom, algoritam*

Face Recognition Software – Abstract

Topic of this paper is the problem of finding efficient software for face recognition and specific adjacent algorithm. The software is based on photographs of people's faces which are a template that are then compared with database of different faces, searching for a match. The first step at any face recognition software is face detection, and then comes face tracking and face recognition. It will be clarified how different terms and conditions of obtaining a photograph of people's faces affect identification, because the faces go through many changes and finding the right software has been a challenge for scientists in the last 20 years. The only similar and currently the best such system, that scientists use as starting point, is human ability of recognizing people i.e. human brain and eyes. Basic starting point for algorithm

development is recognition of a human face through a photograph or a video-based recognition, and problem of the design of this algorithm, which takes into consideration all the conditions in which the face is photographed and all the changes of ageing and the way of life, is the field of interest in this paper. One of the most popular algorithms will be explained (Viola – Jones), as well as software usage for different purposes and comparison with other similar systems.

Keywords: *Face Recognition Software, face detection, face tracking, face recognition, algorithm*

1. UVOD:

Prepoznavanje lica, temeljeno na uobičajenoj, lakoj i uspješnoj ljudskoj aktivnosti, preneseno u računalni softver i algoritam naznačava još niz problema koji su daleko od rješenja, unatoč svim istraživanjima u posljednjih 20 godina. Delač i Grgić [2] napominju da je automatsko prepoznavanje lica zamršeno prvenstveno zbog otežavajućih okolnosti u kojima nastaje fotografija (osvjetljenje i kut fotografiranja mijenjaju se s obzirom na pokrete tijela) i zbog različitih drugih efekata kao što su starenje, izraz lica, različite smetnje itd. Autori navode da istraživači iz područja računalstva, analize i obrade slike, prepoznavanja uzoraka, strojnog učenja i drugih područja rade zajedno, motivirani uglavnom brojnim mogućnostima praktične primjene.

U radu će se objasniti zašto prepoznavanje lica (eng.*face recognition*) uključuje pojmove detekcija lica (eng.*face detection*) i praćenje lica (eng.*face tracking*) te koje su razlike među njima. Obrazložiti će se načini na koji ljudi prepoznaju druge ljude te razjasniti zašto računalnim stručnjacima ova tema treba biti bitna i s biološke strane, jer biometrija ne uključuje samo prepoznavanje lica već i prepoznavanje pomoću otisaka prstiju, šarenice oka, glasa, rukopisa, hoda itd. Delač et al. [1] navode da prepoznavanje lica predstavlja intuitivnu i nenametljivu metodu prepoznavanja ljudi, a to je razlog zašto je postalo jednom od tri metode identifikacije koje se koriste u e-putovnicama i biometrijskim izborima za mnoge druge sigurnosne aplikacije. Međutim, prepoznavanje lica nije moguće ukoliko dolazi do promjene na licima ljudi, od starenja do šminke, puštanja brkova i brade, plastičnih operacija te osvjetljenja i rezolucije fotografije. Ključni cilj računalnog sustava za prepoznavanje lica je da parira ili na kraju čak i nadiđe ljudsku sposobnost prepoznavanja lica.

U radu će se osvrnuti na činjenice da ljudi mogu prepoznati poznata lica na vrlo lošim nisko-rezolucijskim fotografijama, da se mogućnost toleriranja degradacije povećava s poznanstvom, da lice može biti identificirano s vrlo malo informacija tj. za prepoznavanje poznatog lica dovoljno je samo jedno svojstvo (poput očiju ili obrva), prema Sadr et al. u Sinha et al. [8]. Stevanov i Zdravković [3] napominju da su polja bitna za identifikaciju očiju, obrve, vrh nosa i usne, a važni konfiguracioni odnosi su neovisni kroz dimenzije širine i visine. Rad objašnjava zašto karikaturne verzije lica demonstrirano podržavaju performanse prepoznavanja, barem jednako ako ne i bolje nego što to čine istinito prikazana lica te kako boja i pigmentacija igraju važnu ulogu, posebno kad oblik lica na fotografiji izgubi formu. Negativni kontrast slike dramatično narušava prepoznavanje, vjerojatno zbog ugrožene

moгуćnosti uporabe pigmentacije, jer prekida sjenćanje lica (za lica koja su osvjetljena odozgo), a kretnja lica potpomaže daljnje prepoznavanje (facijalne ekspresije). Stevanov i Zdravković [3] objašnjavaju holistički pristup prepoznavanja lica na način da se prepoznavanje temelji na prostornim odnosima između dijelova lica kao i na samom obliku lica. Osobita se pozornost posvetila prepoznavanju lica kroz starenje (pušenje, uporaba narkotika, biološki faktori starenja kao i fizičke promjene nastale plastičnim operacijama). Dodatno će se u radu objasniti trenutačno najaktualniji algoritam Paula Viole i Michaela Jonesa te način njegova funkcioniranja kao i 3D model koji je matematički prikaz bilo kojeg trodimenzionalnog objekta, a postaje grafika tek kada ga se prikaže. Prikazat će se i pozitivne strane prepoznavanja lica preko videa ili *video-based face recognition* (eng. *VFR*) s prikazom primjera bombaškog napada na maratonu u Bostonu 2013. godine.

Principi rada računalnih sustava koji prepoznaju ljudska lica imaju višestruku namjenu u području državne sigurnosti, poboljšanja interakcije između čovjeka i računala i mnogih drugih komercijalnih mogućnosti. U većini zračnih luka svijeta (Portugal, Australia) instalirani su ovakvi sustavi [25]. Vladine organizacije imaju ih u svojim uredima u svrhu nadzora ili praćenja ili ćemo ih vidjeti na ulicama velikih svjetskih metropola (London, Velika Britanija). Za pravilno funkcioniranje softvera za poznavanje lica izuzetno je važno imati aktualizirane baze podataka, što se pojašnjava u posljednjem poglavlju kao i kratka usporedba sa sličnim sustavima.

2. POVIJEST

Delač et al.[1] pojašnjavaju kako je krajem 70-ih godina prošlog stoljeća došlo do razvoja tehnologije, a samim time i do napretka u istraživanju tehnoloških mogućnosti za prepoznavanje lica. Prvi, široko prihvaćeni algoritam u ono doba, bio je *eigenface metoda*, koji se i danas upotrebljava kao početak u mnogim istraživanjima. Članak Paula Viole i Michaela Jones iz 2001. Godine, objavljen 2003. godine, objašnjava najnovija dostignuća vezana uz algoritam, a koji se temelji na *AdaBoost* algoritmu za učenje i koji je prekretnica u ovom polju istraživanja (dalje u poglavlju 6. Algoritam Viola – Jones). U tablici 1 prikazan je povijesni razvoj metoda za prepoznavanje lica.

Godina	Autori	Metoda
1973.	Kanade	Prvi automatizirani sustav
1987.	Sirovich i Kirby	Analiza osnovnih komponenti
1991.	Turk i Pentland	Eigenface
1996.	Etemad i Chellappa	Fisherface
2001.	Viola i Jones	AdaBoost + Haar-like Cascade
2007.	Naruniec i Skarbek	Gabor Jets


Tablica 1. Povijesni razvoj metoda za prepoznavanje lica

3. PROBLEMATIKA PREPOZNAVANJA LICA POMOĆU RAČUNALA

U posljednjih 20 godina znanstvenike iz različitih područja znanosti intrigira problem prepoznavanja lica pomoću računala. Kay Wagers [15] objašnjava kako je softver za prepoznavanje lica „forma biometrijske sigurnosti. To je softver koji bilježi fotografije lica osobe te ih pretvara u predložak. Softver zatim uspoređuje fotografiju s bazom podataka raznih fotografija lica, tražeći podudaranje.“

Biometrija je, prema stranici Answers.ask.com [11] „tehnologija koja se upotrebljava za analizu našeg tijela u svrhu autentikacije.“ Osim prepoznavanja lica, u ovu kategoriju spadaju i prepoznavanje pomoću otisaka prstiju, šarenice oka, glasa, rukopisa, hoda itd.

Prema Chellappa et al. [5] pravi sustav za prepoznavanje lica mora se sastojati od 3 glavna modula: detekcije lica, ekstrakcije svojstva i prepoznavanja lica, kako je shematski prikazano na slici 1.



Slika 1. Shematski prikaz generičkog sustava za prepoznavanje lica s tri glavna modula, prema[5]

Stručnjaci za sustav prepoznavanja lica objašnjavaju da su za prepoznavanje potrebna 3 koraka [32]:

- Detekcija lica (eng. *face detection*) je prvi korak kod bilo kojeg sustava za prepoznavanje lica. Odnosno, radi se o tome može li sustav pronaći tj. identificirati fizičko lice na slici, isječku ili preko video-kamere u realnom vremenu. Kod pravilne detekcije lica prvenstveno je važno da sustav ustanovi na slici (snimci) što je od svega

prikazanog ljudsko lice i razlikuje ga od svega ostaloga. U tom koraku bitno je smanjiti broj lažnih pozitivnih rezultata pomoću gore navedenih ekstrakcija različitih svojstava (slika 1), odnosno kad sustav detektira lice, prema Chellappa et al. [5], svojstva koja se ekstrahiraju mogu se plasirati u sustav klasifikacije lica. Iako ovisi o tipu klasifikacijskog sustava, svojstva mogu biti svakojaka: od teksture do glavnih pouzdanih točaka ili facijalne komponente kao primjerice oči, nos ili usta.

- Praćenje lica sustavom (eng. *face tracking*) podrazumijeva može li se pratiti lice tj. osobu kroz kretnje i različite poze stalno i neprekidno ako se kreće kroz prostoriju ili zgradu
- Prepoznavanje lica sustavom (eng. *face recognition*) je korak koji uzima u obzir lica koja smo pronašli preko detekcije lica, snimke više verzija istog lica dobivene praćenjem osobe kroz prostor (u kretanju) te uspoređivanje toga lica s licem pohranjenim u bazi podataka i identificiranje lica.

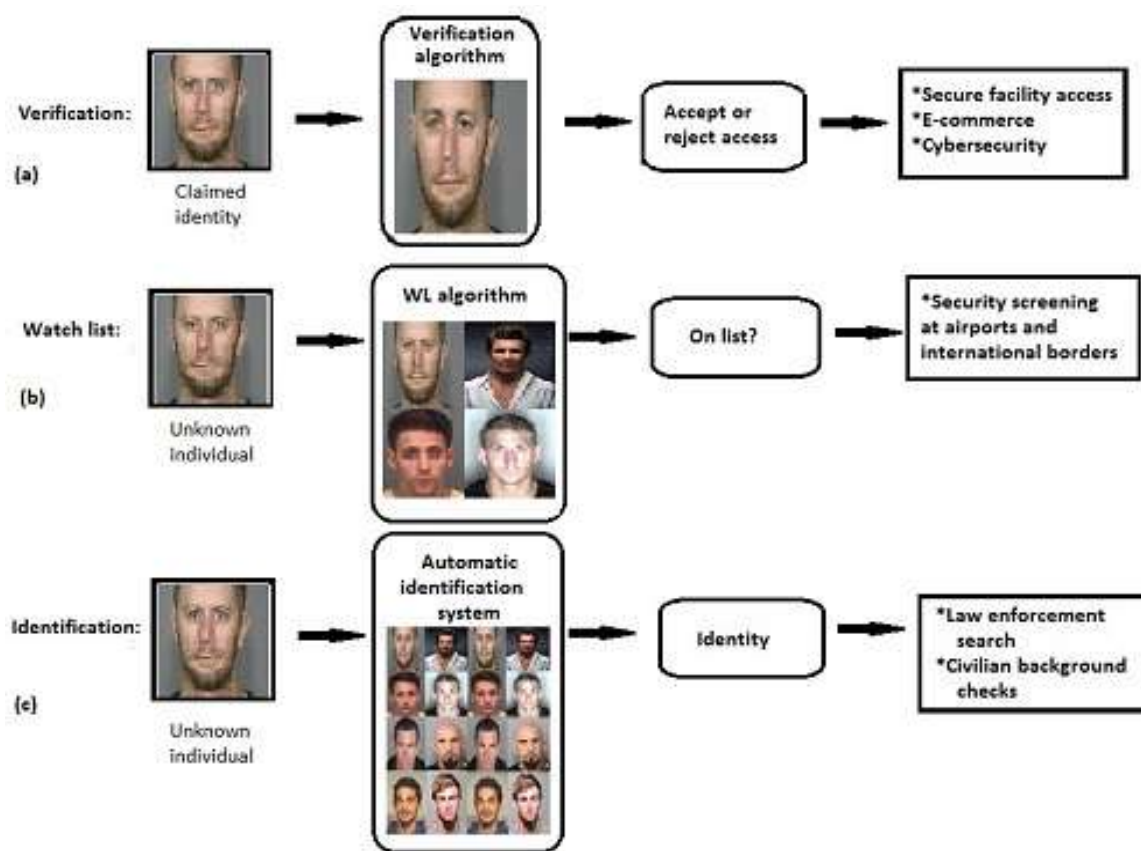
Prepoznavanje lica nije moguće ukoliko dolazi do promjene na licima ljudi, od starenja do šminke, puštanja brkova i brade zatim plastičnih operacija te osvjettljenja i rezolucije, što će sve detaljnije biti objašnjeno u daljnjem tekstu, te na slici 2.



Slika 2. Primjer nenalaženja lica zbog krivog kontrasta između nosa i čela zbog šminke i kose (gornji red), te pozitivni nalaz lica zbog točnih kontrasta, prema [14]

Kod dizajna sustava za prepoznavanje lica, prema Chellappa et al. [5], može se imati na umu 3 zadatka poput (slika 3):

- Verifikacija – sustav određuje poklapa li se osoba na slici s danim identitetom jedne osobe
- Lista osumnjičenih – sustav uspoređuje dano lice u bazi podataka s traženim kriminalcima te ih identificira
- Identifikacija – sustav određuje identitet osobe sa slike (tj. razlikuje jednu osobu od druge)



Slika 3. Dijagram koji pokazuje moguću strukturu zadataka prepoznavanja lica. Ovi zadaci su verifikacija, liste osumnjičenih i identifikacija, prema [5]

Postavlja se problem zašto je prepoznavanje lica tako teško. Prema Chellappa et al. [5] bitni su različiti uvjeti dobivanja slike ljudskih lica jer prolaze kroz mnoge promjene koje bitno utječu na identifikaciju. To su različiti facijalni izrazi, lice promijenjeno zbog prirodnog

starenja te fizički položaj lica u odnosu na kameru, osvjetljenje, nejasne obrise i broj piksela u području lica koje odaje detalje.

Dodatne varijacije mogu biti prerušavanje osobe tj. zaklanjanje lica šeširom i sunčanim naočalama ili facijalnim dlakama. Utjecaj gubitka ili dobitka na težini dodaje još jednu dimenziju u prepoznavanju lica (pobliže objašnjeno kasnije u poglavlju 5. Prepoznavanje lica kroz starenje).

S obzirom na to da ljudi posjeduju nevjerojatne sposobnosti za prepoznavanje lica, znanstvenici i dizajneri ovakvih sustava trebali bi biti svjesni faktora koji utječu na ljudsku percepciju lica.

4. PREPOZNAVANJE LICA KOD LJUDI

Prepoznavanje lica od strane ljudi, prema Stevanov i Zdravković [9], je ključno za identifikaciju drugih ljudi. No, ljudsko lice otkriva nam i mnoge druge stvari, a ne samo identitet osobe. Otkriva nam starost, spol, obiteljsku pripadnost (na osnovi sličnosti), ali i emocionalno stanje i trenutno raspoloženje.

Identifikacija lica kod ljudi moguća je bez velikih mentalnih napora (osim ako osoba ima neki mentalni ili fizički problem koji je sprečava u tome). Dakle, u pitanju je fantastičan proces koji u djelićima sekunde uspoređuje neko lice s licima koja se čuvaju u dugotrajnoj memoriji ljudi.

Ključni cilj računalnog sustava za prepoznavanje lica je da parira ili na kraju čak i nadide ljudsku sposobnost prepoznavanja lica.

Naime, trenutni problemi s kojima se znanstvenici, prema [8, 5], susreću oko kreiranja ovakvih sustava su udaljenost, kvaliteta slike i pikselizacija, osvjetljenje, facijalni izrazi (emocije) kao i opsežnost same baze podataka.

Kako bi znanstvenici izradili što bolji i učinkovitiji sustav, trebali bi se obratiti poznatome tj. možda će bolje shvatiti princip rada ako pogledaju slične sustave. U ovom slučaju, jedini sličan i trenutno najbolji sustav je ljudska sposobnost prepoznavanja ljudi tj. ljudski mozak i oči.

4.1. Prepoznavanje kao funkcija dostupnih prostornih rezolucija

Prostorna rezolucija (eng. *Spatial resolution*) je izraz koji se odnosi na broj piksela korištenih u konstrukciji digitalnih fotografija. Fotografije koje imaju višu prostornu rezoluciju sastavljene su od većeg broja piksela nego one s niskom prostornom rezolucijom [21].

Rezultat 1. Ljudi mogu prepoznati poznata lica na vrlo lošim nisko-rezolucijskim fotografijama

Zbog ubrzanog napretka u rezoluciji kamera znanstvenici su se našli pred iskušenjem kako povećati količinu detalja koji predstavljaju lice (trenutno rekord drži američka vlada s ARGUS-IS kamerom od 1,8 gigapixelsa [12]). Razlika između prepoznavanja različitih pojedinaca mogla bi biti znatno povećana zbog tih visoko rezolucijskih kamera na temelju suptilnih razlika u facijalnim značajkama. Primjer toga su sustavi temeljeni na prepoznavanju šarenica oka (eng. *Iris-based biometric system*), a najveći razlog poteškoća pri povećanju detalja i količine piksela je problem udaljenosti. Nije isto ako osoba stoji metar ili 5 metara udaljena od kamere koja je snima.

Naravno da su takve kamere skupe i da se nikad ne radi o samo jednoj kameri. Cijeni treba dodati i cijenu samog sustava za više računala, a to je iznos koji si mnogi ne mogu priuštiti.

Rezultat 2. Mogućnost toleriranja degradacije povećava se s poznavanjem

Ljudska mogućnost prepoznavanja visoko degradiranih fotografija lica (fotografije slabe razlučivosti) dramatično se povećava s količinom prisnosti. Bruce et al. kao i Burton et al. u Sinha et al. [8] dalje u svom članku objašnjavaju koliko je zahtjevan zadatak spajanja dviju različitih fotografija iste nepoznate osobe dok je zadatak puno lakši kad jedna osoba prepoznaje poznate osobe bez obzira na degradaciju fotografije (vidi sliku 4).

Dodatno, struktura tijela i način hoda predstavljaju manje korisne informacije za identifikaciju od facijalnih informacija.



Slika 4. Unatoč degradacijama, Sinha et al. [8] pojašnjavaju kako je lakše prepoznati već poznatu osobu sa slike nego osobu koju smo vidjeli samo jednom. Na primjer, ispitanici su prepoznali više od polovice svih poznatih lica prikazanih u gore prikazanoj rezoluciji. Osobe prikazane po redu su: Michael Jordan, Woody Allen, Goliie Hawn, Bill Clinton, Tom Hanks, Saddam Hussein, Elvis Presley, Jay Leno, Dustin Hoffman, Prince Charles, Cher, Richard Nixon

4.2. Prirodnost procesiranja: Dio po dio ili u cjelini

Rezultat 4. *Facijalna svojstva su procesirana holistički odnosno kao cjelina.*

U Sinha et.al. [8] pitaju se mogu li facijalna svojstva (oči, nos, usta, obrve, itd.) biti procesirana odvojeno od ostatka lica. Prema Sadr et al. u Sinha et al. [8] lice može biti identificirano s vrlo malo informacija tj. za prepoznavanje poznatog lica dovoljno je samo jedno svojstvo (poput očiju ili obrva). Chellapa et al. [5] također smatraju da su obrve jedno od najvažnijih facijalnih svojstava za prepoznavanje. Izgleda da holistički kontekst utječe na to kako su individualna svojstva procesirana.

Dalje o holističkoj strategiji u Rezultatu 16.

Rezultat 5. *Od različitih facijalnih svojstava, obrve su među najvažnijima za prepoznavanje*

Nisu sva facijalna svojstva tretirana jednako u uvjetima njihove uloge kod pomaganja identifikacije lica. Sadr et al. u Sinha et al. [8] sugerira da su obrve među najvažnijim svojstvima, čak u usporedbi s očima (slika 5).

Naime, čini se da su obrve vrlo bitne za prijenos emocija kao i ostalih neverbalnih signala tvrde Chellappa et al. [5]. Osim toga, čini se da su obrve vrlo *stabilno* facijalno svojstvo zato što imaju tendenciju biti relativno velik kontrast i veliko facijalno svojstvo te mogu preživjeti bitnu fotografsku degradaciju.

Također je bitno naglasiti da ljudi posjeduju veliki raspon fizičkih pokreta obrva koji se ne mogu mjeriti s pokretima očiju ili usta.

Prema istraživanju koje su provele Stevanov i Zdravković [3] s obzirom na prepoznavanje osobe na temelju pojedinačnih facijalnih svojstava, može se zaključiti da su polja bitna za identifikaciju očiju, obrva, vrh nosa i usne. Također je bitno naglasiti da se identitet osobe može odrediti već na osnovi jednog ili dva dijela lica kao što su usne ili oči i vrh nosa.



Slika 5. Primjer iz istraživanja Sadr et al. u Sinha et al. [8] u kojem se procjenjuje uloga obrva kod prepoznavanja lica: originalne slike bivšeg Predsjednika SAD-a Richarda M. Nixona i američke glumice Winone Ryder, zajedno s modificiranim verzijama bez obrva ili očiju

Rezultat 6. *Važni konfiguracijski odnosi su neovisni kroz dimenzije širine i visine*

Prema Sinha et al.[8] neki računalni vizualni sustavi uključuju točna mjerenja atributa poput unutarnje udaljenosti razmaka između očiju, širine usta, dužine nosa, itd. No, izgleda da ljudski vizualni sustav ne ovisi kritički o ovim mjerama. Dokazi u korist ove tvrdnje su

istraživanja prepoznavanja s iskrivljenim slikama lica. Izgleda da se ljudski vizualni sustav adaptirao na problem oko odnosa iso-dimenzija (odnos udaljenosti kroz x i y dimenziju) te je bitno kodirati toleranciju na takve transformacije kod računalnih sustava.



Slika 6. Čak i drastične kompresije lica ne čine ih neprepoznatljivima. Ovdje su lica komprimirana na 25% njihove originalne širine no unatoč tome prepoznavanje se nije smanjilo, prema [8]

4.3. Pigmentacija, oblik, pokret

Rezultat 7. Oblik lica kodiran je prepoznavanjem karikiranih lica

Intuitivno, prema Sinha et al. [8], uspješno prepoznavanje lica zahtijeva da ljudski vizualni sustav kodira prije viđena lica istinitima. Greške u spremljenom prikazu lica očito smanjuju potencijal spajanja novog unosa sa starim.

Unatoč tome, prema demonstraciji, neka odudaranja od istinitog prepoznavanja su čak djelotvornija za ljudsko prepoznavanje lica. Točnije, karikaturne verzije lica demonstrirano podržavaju performanse prepoznavanja, barem jednako ako ne i bolje nego što je postignuto s istinitim licima. Karikirana lica mogu naime biti kreirana do mjere pretjerivanja u devijacijama oblika ili kombinacijama devijacija i oblika te pigmentacije. U oba slučaja subjekti preferiraju manju ali konzistentnu sklonost prema karikaturnim licima što je potvrdilo nekoliko različitih mjera.

Ovi rezultati uzeti su kao prijedlog za normu *prostor za lica*, također još imenovanima u literaturi kao *prostor lica* (eng. *Face space*).


Rezultat 9. *Pigmentacija je jednako važna kao oblik*

Postoje dva osnovna načina po kojima razlikujemo lica: po obliku i po načinu na koji reflektira svjetlost tj. pigmentacija. Pod terminom *pigmentacija*, u Sinha et al. [8], misli se na sve površine s reflektirajućim svojstvima, uključujući *albedo*, nijanse, odražavanje, providnost te prostornu varijaciju tih svojstava. U nastavku se objašnjavaju navedeni termini pigmentacije:

Albedo (eng. *Albedo*) [31] – mjera moći odbijanja svjetlosti koju ima neka površina ili tijelo. To je omjer odbijenog i primljenog elektromagnetskog zračenja. Omjer ovisi o frekvenciji i upadnom kutu razmatranog zračenja. Ako nije posebno navedeno, podrazumijeva se prosjek unutar spektra vidljive svjetlosti koja pada okomito na površinu.

Nijanse (eng. *Hue*) [28, 27] – glavno svojstvo boje, iako je ponegdje definirano tehnički (npr. hex vrijednost za „tamno crvenu nijansu“ može biti #660000), zapravo označava različite stupnjeve nijansi neke boje, npr. svijetlo-plava, tamno-plava, nebesko-plava...

Odražavanje (eng. *Specularity*) [29] – vizualni izgled odražavajućih odsjaja. U kompjuterskoj grafici, to znači kvantitetu upotrebljavanu u trodimenzionalnom (3D) renderiranju što predstavlja iznos odražavajuće površine (koju neka površina ima). To je ključna komponenta u određivanju svjetline odražavajućih površina, kao i sjaj koji određuje veličinu površine (slika 9).



Slika 9. Primjer reflektirajuće površine, prema [29]

Providnost (eng. *Translucency*) [30] – providan medij dopušta prijenos svjetlosti no ne dopušta stvaranje odraza slike (sjene) poput prozirnog medija (slika 10).




Slika 10. Primjer providnog medija[30]

Kad objašnjavamo pojam *sva svojstva reflektirajuće površine lica*, radije upotrebljavamo izraz *pigmentacija ili izgled površine* u usporedbi s pojmovima *tekstura* ili *boja*, što izaziva zbunjenost jer ti pojmovi označavaju svojstva refleksije površine.

Rezultat 10. Boja igra važnu ulogu, posebno kad oblik lica na fotografiji izgubi formu

Osvijetljena struktura slike lica sigurno je od najveće važnosti za prepoznavanje lica. Prema Sinha et al.[8], ljudi imaju veću tendenciju prepoznavanja lica kad su lica u boji. Dapače, kad su oblici na slikama smanjeni (primjerice zbog redukcije u rezoluciji), mozak se oslanja na boju detalja kod prepoznavanja identiteta. U tim okolnostima, prepoznavanje u boji je puno veće nego kod crno-bijelih slika. Sinha et al.[8] objašnjavaju kako distribucija boja može nadomjestiti informacije osvjetljavanja da bi dopustila bolju procjenu ograničenja, oblika i veličina facijalnih atributa kao što su oči i linija kose. Chellappa et al. [5] se slažu s ovim tvrdnjama te dodaju kako također inverzija boja onemogućava prepoznavanje zbog ugroženosti pigmentacije i osvjetljenja. Potvrdu toga nalazimo kod kretanja osobe. Naime, različitim kretnjama osobe lice je osvjetljeno iz različitih kutova upadne svjetlosti te je samim time i prepoznatljivost lica drugačija (vidi sliku 7.).

Ono što je možda dodatno zanimljivo je, prema Yip i Sinha (2001.) u Gorodnichy [6], da tvrdnja da boja ne utječe na prepoznavanje, kako kod ljudi tako i kod računalnih sustava.



Slika 7. Različit prikaz lica iste individue prema varijacijama u starenju (prvi red odozgo), zatim u drugom redu prikaz različitih poza, u trećem redu prikaz različitih izraza lica te u zadnjem redu prikaz osvjetljenja i oštine slike, prema [5]

Ove nalaze dalje potvrđuju rezultati navedeni pod 11.

Rezultat 11: Negativni kontrast slike dramatično narušava prepoznavanje, vjerojatno zbog ugrožene mogućnosti uporabe pigmentacije.

Kad su pigmentacijske mogućnosti nedostupne, prepoznavanje lica nije puno lošije od negativnog kontrasta. Negativan kontrast naime prekida sjenčanje lica (za lica koja su osvijetljena odozgo). Ti nalazi, prema Sinha et al. [8], upućuju na to da prepoznavanje lica koristi zastupljenost osjetljivosti na smjer kontrasta te ukazuje da pigmentacija i sjenčanje čine bitnu ulogu kod prepoznavanja lica.

Spomenuti su pojmovi bitni za prepoznavanje lica, a to su poza (eng. *Pose*), osvjetljenje (eng. *Illumination*) i izraz lica (eng. *Expression*), što prema Chellappa et al. [5] tvore kraticu PIE.

Ovi pojmovi su bitni kod izrada 3D modela lica pomoću slika (više u poglavlju 7. 3D Modeli.).

Rezultat 12. *Osvjetljenje mijenja utjecaj generalizacije.*

Prema Sinha et al. [8], neki računalni modeli prepoznavanja pretpostavljaju da lice mora biti viđeno pod puno različitih uvjeta osvjetljenja da bi krajnji prikaz bio dobar. Nadalje, objašnjava se kako je ljudska mogućnost prepoznavanja lica osjetljiva na smjer osvjetljenja, ali je također i u mogućnosti generalizirati nove uvjete rasvjete nakon viđenja samo jedne slike.

Rezultat 14. *Čini se da kretanja lica potpomaže daljnje prepoznavanje*


Kruto tj. nefleksibilno (eng. *Rigid*) kretanje (poput kamere koja se okreće oko nepomične glave), prema Sinha et al. [8], može pomoći kod prepoznavanja već viđenih lica. Suprotno tome, ne-kruto tj. fleksibilno (eng. *Nonrigid*) kretanje (tj. slučajevi kad pojedinci pokazuju emotivne facijalne ekspresije ili pokrete kod govora) ima veću ulogu kod prepoznavanja. Naime, takav slučaj može čak dovesti do toga da subjekt krivo prepozna odnosno zamijeni osobe kod prepoznavanja (nepoznatih) osoba jer je subjektivan kad se radi o facijalnim ekspresijama.

Prema Chellappa et al. [5] facijalni identitet i ekspresije bi mogle biti obrađene kroz odvojene sustave, iako su na raspolaganju razne tehnike za automatsko prepoznavanje izraza. Te tehnike su najučinkovitije za makroekspresije poput radosti, ljutnje, iznenađenja ili straha. Suprotno tome, analiza i prepoznavanje mikroekspresija još je uvijek aktivno područje za istraživanje. O time pišu i Sinha et al. [8] te spominju nove teoretske modele i modele neuralnih sustava koji predlažu odvajanje identificiranja od procesiranja ekspresija.

4.4. Razvojno napredovanje

Rezultat 15: *Vizualni sustav počinje s osnovnim prioritetima prema oblicima koji nalikuju na lica*

Prema Sinha et al. [8], novorođenčad, samo nekoliko sati nakon rođenja, selektivno promatra samo oblike koji nalikuju na ljudska lica. Tri točke raspoređene unutar ovalnog oblika predstavljaju dva oka i usta, a navedeno spominju i Stevanov i Zdravković [3] u svom znanstvenom članku. Odnosno, prema daljnjem istraživanju Simion et al. u Sinha et al. [8], tvrde da novorođenčad više vole grupiranje oblika na gornjem dijelu nego na donjem dijelu objekta (slika 8.).



Slika 8. Gornji red prikazuje geometrijske uzorke dok donji red prikazuje figure koje nalikuju na ljudska lica. Novorođenče će prije reagirati na prvi tj. lijevi primjer nego na desni

Iz ovih rezultata može se zaključiti da se pri detekciji lica mogu koristiti tri točke unutar ovalnog oblika kao prikladan predložak za detektiranje lica u početnim fazama sustava koji prepoznaje lica.

Rezultat 16: *Vizualni sustav napreduje sa strategije razdvojene na dijelove na holističku strategiju*

Holistička strategija je spomenuta već u tekstu kod Rezultata 4.

Normalni odrasli ljudi pokazuju zaprepašujući nedostatak mogućnosti kod prepoznavanja izokrenutih lica za razliku od normalno uspravljenih lica. Taj je nedostatak mnogo manji za

slike objekata bez lica poput primjerice kuće. Prema Sinha et al. [8] taj deficit se razvijao godinama, jer djeca starosti 6 godina nisu pod tolikim utjecajem prepoznavanja izokrenutih lica poput odraslih. Osmogodišnjaci pokazuju neke znakove da prepoznavanje izokrenutih lica utječe na njih dok desetogodišnjaci pokazuju gotovo iste probleme kao i odrasli.

Izgleda kao da kod ljudi procesiranje prostora sazrijeva kasnije nego procesiranje svojstava. Prema Chellappa et al. [5] facijalna svojstva procesirana su holistički, iako je priroda prepoznavanja lica razdvojena na dijelove.

Stevanov i Zdravković [3] objašnjavaju holistički pristup prepoznavanja lica na način da se prepoznavanje temelji na prostornim odnosima između dijelova lica kao i na samom obliku lica. Druga strategija odvajanja na dijelove usmjerena je prema proučavanju pojedinačnih dijelova lica.

Isti autori su također proveli istraživanje ovog svojstva te zaključili kako je određivanje identiteta osobe moguće na osnovi informacija koje pružaju pojedinačni dijelovi lica. U tom istraživanju lica su bila pokrivena, a ispitanici su mogli otvarati jedan po jedan dio maske u pokušaju da što brže otkriju identitet osobe. Određivanje identiteta je naime moguće, kako je već prije naglašeno, na temelju informacija koje pružaju pojedinačni dijelovi lica (npr. oči, obrve, vrh nosa itd.). Dodatno je otkriveno, prema istraživanju Stevanov i Zdravković [3], da ispitanici pri identifikaciji preferiraju lijevu stranu lica. Odnosno, tipičan redoslijed otkrivanja dijelova lica za prepoznavanje je – lijevo oko, lijeva obrva, vrh nosa, desno oko, usne, razmak između očiju, desna obrva, razmak između obrva, gornji lijevi obraz, gornji desni obraz, itd.

Rezultat 18: Latentnost odgovora na lica u IT (Infero-Temporal) korteksu je oko 120 ms, sugerirajući velike napredne izračune

Ljudski promatrači mogu izvršiti zadatke vizualnog prepoznavanja vrlo brzo. Prema Sinha et al. [8], postoje neuropsihološki dokazi da se jako kompleksni zadaci, poput prepoznavanja lica, mogu dogoditi kroz iznenađujuće brz period. Latentnost odgovora je oko 80-160 ms, s time da su neki rezultati pokazali i brzinu od čak 50 ms.

5. PREPOZNAVANJE LICA KROZ STARENJE

U definiranju problematike prepoznavanja lica pomoću računala spomenuto je starenje kao jedan od problema u mogućoj identifikaciji osobe (slika 7). Prema Chellappa et al. [5] taj problem je izazov, jer mora objediniti sve ostale varijante tj. pozu, izraze i osvjetljenje kroz nastale u procesu starenja tj. uzima u obzir godine razlike. Teksturalna svojstva kože također mogu varirati zbog šminke, naočala, gubitka težine, gubitka kose i tako dalje.

Facijalne promjene mogu se također dogoditi zbog nekoliko ekoloških faktora kao što su solarna radijacija, pušenje, uporaba narkotika (slika 11) te razina stresa.



Slika 11. Promjene na licu nastale uslijed uporabe narkotika kroz godine

Biološki i ekološki faktori mogu ili odgoditi ili ubrzati proces starenja. Starenje se odvija i kod tvrdog i kod mekog facijalnog tkiva. Gubitak elastičnosti tkiva, facijalnog volumena i promjena u teksturi kože također se događa zajedno sa starenjem. Neke osobe ovu prirodnu fizičku promjenu pokušavaju usporiti plastičnim operacijama (slika 12).



Slika 12. Promjene na licu nastale zbog plastičnih operacija

Iako je način starenja nepredvidiv, čini se da slijed promjena prati osnovni progresivni obrazac kroz vrijeme.

Chellappa et al. [5] nastavljaju dalje objašnjavajući kako se najveće promjene u smislu starenja događaju između druge i osamnaeste godine života. Kod starijih subjekata, varijacije kod facijalnih tekstura više su usmjerene na oblik. Ove zaključke donijeli su i psihofizičari i računalni istraživači. Psihofizičke metode uključuju praćenje promjena i varijacije kod oblika i stupnja nabora na koži te pretjeravanje ili nenaglašavanje facijalnih nabora. Računalni istraživači predložili su računalne modele rasta koji funkcioniraju i prate pristup računalnog učenja za prepoznavanje lica kroz starenje.

6. ALGORITAM VIOLA – JONES

Dizajneri jednog od najpopularnijih i robusnijih algoritama za detekciju lica su Paul Viola i Michael Jones. Objasnili su rad svog algoritma u članku iz 2003. godine, koji je objavljen u *International Journal of Computer Vision* 2004. godine pod nazivom *Robust Real-Time Face Detection*.


Chellappa et al. [5] su predstavili pristup strojnog učenja za detekciju objekata prema učenju jakog klasifikatora kroz opterećenu kombinaciju nekoliko slabih učenja. Dakle, algoritam koji uči, temeljen je na Adaboost-u (algoritam za učenje, Freund i Schapire, 1995.), odabire mali broj kritičkih vizualnih svojstava koji pružaju najbolju preciznost kod klasifikacije (slika 13).



Slika 13. Primjer tipične detekcije lica i algoritma detekcije svojstva i ekstrakcije tih svojstava, prema Chellappa et al. [5]

Ova procedura za detekciju lica, kako objašnjavaju Viola i Jones [10], klasificira slike na temelju vrijednosti nekoliko jednostavnih svojstava. Postoji više razloga za upotrebu svojstava umjesto direktne upotrebe piksela. Najčešći razlog je da se svojstva mogu praviti da kodiraju znanje u ovu svrhu, koje je teško inače naučiti upotrebljavajući konačnu količinu podataka za učenje. Za ovaj sustav upotrebe svojstava također postoji i drugi kritični razlog. Sustavi koji su temeljeni na svojstvima operiraju puno brže nego sustavi temeljeni na pikselima, a samim time su i jeftiniji.

Ta jednostavna svojstva su dio tzv. Haar-bazirane funkcije (algoritam koji se bazira na pojavi - u usporedbi s algoritmima koji su bazirani na učenju), koju su prvi spomenuli Papageorgiou et al. (1998.). Dakle to su XML dosjei koji definiraju kaskadni set svojstava (Haar-svojstva) na digitalnim slikama upotrebljavane za prepoznavanje objekata. Dakle Viola i Jones su adaptirali ovu ideju i nazvali ta svojstva Haar-like svojstva [19] (slika 14).



Slika 14. Primjer usporenog izračuna Haar-like svojstva prema Viola – Jones algoritmu te mora biti barem 3 preklapajuća crna kvadrata preko lica da bi se dobila 99% točnost da je na slici lice tj. izbjegava se tzv. false-pozitive rezultat, prema [19]


Viola i Jones [10] nadalje objašnjavaju u svom radu da upotrebljavaju 3 vrste *Haar-like* svojstava odnosno svojstava koja su zapravo matematičke funkcije koje produciraju pravokutni oblik unutar podataka. Dakle, riječ svojstvo u ovom slučaju se ne odnosi na facijalno svojstvo. Ova svojstva mogu biti različite orijentacije – rubne, linijske i centralizirane.

Prema [26], prva vrsta je vrijednost svojstva dva pravokutnika (eng. *Two-rectangle feature*) koja predstavlja razliku između sume piksela unutar dva pravokutna područja. Područja imaju istu veličinu i oblik te su horizontalno i vertikalno susjedni.

Druga vrijednost su svojstva tri pravokutnika (eng. *Three-rectangle feature*) koja izračunavaju sumu unutar dva vanjska pravokutnika oduzeta od sume centralnog pravokutnika.

Na kraju, treća vrijednost je vrijednost svojstava četiriju pravokutnika (eng. *Four-rectangle feature*) koja izračunavaju razliku između dijagonalnih parova pravokutnika.

Znajući da je baza rezolucije kod detektiranja 24 x 24, iscrpan set pravokutnih svojstava je dosta velik tj. iznosi 160.000 (slika 15).




Slika 15. Primjer pravokutnih svojstava pokazanih relativne uz ograničavajući okvir detekcije. Suma piksela koji leže unutar bijelih pravokutnika su oduzeti od sume piksela u sivim pravokutnicima. Svojstva dvaju pravokutnika su prikazani u slučajevima pod A i B. Slučaj C pokazuje svojstva triju kvadrata i pod D su svojstva četiriju kvadrata

Dakle, Viola – Jones algoritam [10] traži razliku između svjetlijih i tamnijih područja i određuje je li razlika između sume bijelih piksela oduzete od sume crnih piksela unutar okvira onoga što se želi postići. Ovi pragovi su fino podešeni brojevi s pomičnim zarezom. Ako suma stadija ne prođe prag kriterija, rezultat je odbačen i podskeniranje je zaustavljeno. Algoritam zatim pomakne skenirajući podprozor (okvir) na novu lokaciju i izračunava novu sumu. Ako je prag zadovoljen, algoritam nastavlja kroz ostale stadije kaskade (uobičajeno ih ima 20 ili 30). No ako je samo jedan pozitivan rezultat, to ne čini pronalazak lica. Na kraju skeniranja slike, algoritam će promijeniti veličinu skenirajućeg prozora (okvira) za faktor oko 1,3. Nakon što su sva skeniranja dovršena, novi će algoritam izračunati preklapanje ovih pravokutnika i, ako je dovoljno preklapanja (inače je 3), područje vjerojatno predstavlja lice.

No, jedno preklapanje, tj. klasifikator, neće biti dovoljno. Jedno preklapanje zove se *slabi klasifikator* zbog toga što jedno preklapanje donosi vjerojatnost od jedva 50% da je upravo dio određene slike lice, što je na kraju premalo.


Ako određeni dio prođe *slabi klasifikator 1*, mora proći *slabi klasifikator 2* te *slabi klasifikator 3* i tek tada je to vrlo vjerojatno lice. Ako ne pokaže isto mjesto 3 puta, znači nije lice (slika 16).



Slika 16. Primjer Haar-like klasifikatora koji se moraju poklapati radi prikaza lica


Cijeli proces skeniranja može biti prikazan kao podprozor (okvir) koji skenira s lijeva nadesno, odozgo prema dolje, preko cijele slike. Nakon što se završi potpuno skeniranje, podprozor se poveća i cijeli proces se ponavlja. U usporenoj verziji to bi izgledalo kao već gore spomenuta slika 12 ili video na internetu [24].

Bitno je, dakle, naći osobu na slici i odvojiti je od ostatka slike tj. pozadine (slika 17).



Slika 17. Osoba s lijeve strane sjedi ispred police pune knjiga te ju je potrebno Haar-like kaskadama odvojiti od njih, dok na desnoj fotografiji imamo 4 već pronađene osobe

Sva skeniranja Haar klasifikatora su računalno spora i skupa, kako objašnjava [22]. Da bi popravili brzinu ovih izračuna koristi se integralna slika. Viola i Jones [10] objašnjavaju kako integralna slika na lokaciji x,y sadrži sumu pixela iznad i s lijeve strane od x,y (slika 18)



Slika 18. Vrijednost integralne slike na točki (x,y) je suma svih piksela gore i lijevo

Softver za prepoznavanje lica unatoč uspješnosti ovog algoritma, prema TechRadar stranici [22], može biti prevaren tj. stopa lažno pozitivnih rezultata (detektiranje lica gdje ga nema) je ispod 40% ili lažno negativnih rezultata (ne detektiranje lica koje je prisutno) je manje od jedan posto.

Dakle, potrebno je istrenirati sustav da prepozna je li nešto lice ili ne. Tada na scenu stupa AdaBoost. Prema Viola i Jones [10] to je agresivni mehanizam za odabir malog seta dobrih klasifikacijskih funkcija koji unatoč tome imaju određenu raznolikost.

Ako se povuče analogija između slabog klasifikatora i svojstva, AdaBoost je djelotvorna procedura za pretraživanje malog broja dobrih *svojstava* koji unatoč tome imaju određenu raznolikost.

7. 3D MODELI

„3D model je matematički prikaz bilo kojeg trodimenzionalnog objekta, a postaje grafika tek kada ga se prikaže“ („*Tesla*“ *grafičke kartice bez video izlaza, prema: Vrste prikaza 3D modela, Nastavni materijali predmeta Digitalizacija 3D objekata i prostora, prof. dr. sc. Hrvoje Stančić, 2012.,[34]*)

Već je prije spomenuto da se ljudsko lice stalno mijenja. Promjene kod poza, osvjetljenosti te izraza lica (eng. *PIE*) najviše utječu na sustav te nemogućnost prepoznavanja. Fotografije u bazama podataka su najčešće fotografije uzete za državne dokumente tj. putovnicu, osobnu kartu i vozačku dozvolu. Prema Gorodnichy [6] te su fotografije napravljene prema vrlo kontroliranim uvjetima osvjetljenja, odličnim fokusom te visokom rezolucijom (60 piksela između očiju). Gorodnichy [6] nadalje objašnjava da postoje stroga pravila kod ovih fotografija: „osoba mora gledati ravno u kameru, ne pokazujući neobični facijalni izraz ili nositi ikakav objekt na licu koji zaklanja lice“.



Slika 18. Primjer izrade 3D modela iz slika s interneta (prva slika iz svakog reda, ostale su generirani modeli za različite poze)

Da bi kompenzirali nedostatke (odgovarajuća poza na fotografiji), kod usporedbe fotografije iz baze podataka i dobivene fotografije, znanstvenici su prema Chellappa et al. [5] izradili 3D model i generirali 2D reprezentacije za višestruke poze (slika 18, 19, 20).



Slika 19. Primjer fotografiranja objekta za 3D prikaz. Potrebno je fotografirati što više pravilno poredanih fotografija kako bi se dobio što točniji prikaz 3D modela (vlastita zbirka, Lucija Urek)

Linearna kombinacija seta 3D primjera lica pruža parametre za oblik i teksturu, a parametri su procijenjeni prema spojenosti modela u ulaznu sliku. Dosljedno, pristup 3D spajajućeg modela, pružio je visoku stopu prepoznavanja kod prepoznavanja ne-frontalnih lica.



Slika 20. Meduza Rondanini (skenirano u okviru predmeta „Digitalizacija 3D objekata i prostora“ u Gliptoteci HAZU, ak. god. 2011./2012., skenirala (Autodesk 123D Catch) i pretvorila, iz gore navedenih fotografija, u 3D model Lucija Urek [33])

Prema Chellappa i Zhou u Li i Jain [3] postoje nedavna istraživanja oko varijacija rukovanja s pozom i osvjetljenjem koji stvaraju 3D model, eksplicitno ili implicitno. Romdhani et al. prema Chellappa i Zhou u Li i Jain [3] pokazao je kako se 3D model lica može upotrebljavati eksplicitno da bi se stvorila nepoznata poza. Zhou i Chellappa prema Chellappa i Zhou u Li i Jain [3] upotrijebili su 3D model implicitno da bi se ponovo stvorilo osvjetljenje.

Objekti gore navedene metode su bazirane na modelima i fotografijama bez pokreta.

8. PREPOZNAVANJE LICA PREKO VIDEOA

Engleski izraz za ovakvu vrstu prepoznavanja je *video-based face recognition* (eng. *VFR*) te će dalje u tekstu biti korišten akronim VFR.

Općenito, objašnjavaju Chellappa i Zhou u Li i Jain [3], video sekvenca je zapravo zbirka fotografija bez pokreta te je na njih moguće primijeniti algoritme za prepoznavanje osoba na fotografijama. Problematika prepoznavanja lica preko videa je u kvaliteti slike, što uvelike ovisi o kvaliteti same videokamere i udaljenosti kamere od lica osobe, kutu snimanja lica te količini kamera koje snimaju u danom trenutku.

U ovo područje pripada već spomenuto praćenje lica (eng. *Face tracking*) kroz područje snimanja (npr. zgrada) radi dobivanja fotografija lica iz različitih kutova snimanja. Ovakve kamere trebaju biti stabilno postavljene radi robusnog praćenja lica koje se kreće prije nego se može identificirati.

Pozitivne strane ovakvog načina prepoznavanja su velike. Prema Chellappa et al. [5] VFR može prepoznati identitet više osoba prikazanih u videu. Ovakav način prepoznavanja kombinira vremenske osobitosti s facijalnim kretnjama i promjenama u vanjskom izgledu osobe. VFR posebno može biti korišteno u nadziranju, u osiguranju tj. zaštiti od neželjenih osoba te u razne komercijalne svrhe, što će kasnije biti dodatno pojašnjeno.

Način na koji radi tipični VFR sustav jest da prikuplja video signal iz jedne ili više kamera, traka ili segmentiranih lica iz ulaznih signala, zatim se vadi reprezentativni prikaz koji može okarakterizirati identitet osobe, tj. lica iz videa te ga se uspoređuje s već upisanim reprezentativnim subjektima u bazi podataka.

Idealni VFR sustav provodi ove operacije automatski, bez ljudske intervencije.

8.1.Primjer

Klontz i Jain [7] napisali su članak odnosno proveli istraživanje na temu postavljanja bombe 15. travnja 2013. godine na maratonu u Bostonu (SAD). Naime, netko je postavio dvije bombe blizu cilja maratona te ubio tri osobe i ranio 264 osobe. Američka savezna kriminalističko-istražna i obavještajna agencija Ministarstva pravosuđa (eng. *Federal Bureau of Investigation - FBI*) odmah je preuzela slučaj te ograničila područje kretanja ljudi i preuzela ispitivanje sumnjivaca. Pod razne dokaze preuzeli su i *veliku količinu raznih snimki video nadzora okolnih poslovnih ureda*. Tri dana nakon napada, FBI objavljuje fotografije sumnjivaca i traži javnost da pomogne pri njihovom identificiranju (slika 21). Dan kasnije sumnjivce identificira njihova teta tako što je nazvala FBI.

Sumnjivci su bili identificirani kao braća Tamerlan Tsarnaev and Dzhokhar Tsarnaev. To je isprovociralo braću na daljnji pohod u kojem su pri bježanju oteli automobil i ubili zaštitara na MIT-u, što je na kraju završilo time da je policija ubila jednog od braće, a drugog ranila i uhitila.



Slika 21. Objavljene fotografije sumnjivaca za bombaške napade u Bostonu. Kasnije su identificirani kao braća Tamerlan Tsarnaev (s crnom šiltericom) i Dzhokhar Tsarnaev (s bijelom šiltericom) [7]

Ovaj je primjer bitan upravo zato što je od bombardiranja do identificiranja sumnjivaca prošlo 88 sati te niti jedan softver za prepoznavanje lica nije uspio identificirati sumnjivce iako je njihova slika bila u službenoj državnoj bazi podataka (slika 22.).



Slika 20. Vremenska linija događaja istrage vezane uz bombardiranje Bostonskog maratona.

Linija prikazuje mogućnost od 88 sati u kojima je prepoznavanje lica moglo koristiti [7]

Glavni razlog neuspjeha su, navode Klontz i Jain [7], već prije spomenute poza, osvjetljenje, rezolucija, izrazi lica ali i, u ovom slučaju, naočale koje su pokrivale lice jednog od osumnjičenika.

9. UPORABA

9.1. Državna sigurnost

U prethodnom poglavlju naveden je primjer uporabe ovakvih računalnih softvera u svrhu zaštite državne sigurnosti u slučajevima prijetnji terorizmom.

Prema nekim podacima s interneta iz 2012. godine, savezna kriminalističko-istražna i obavještajna agencija Ministarstva pravosuđa Sjedinjenih Američkih država (FBI) [20,17,16] razmjenjuje softver za prepoznavanje lica s uredima policije i raznim agencijama diljem SAD-a.

Radi se naime o pilot-programu pod nazivom *Universal Face workstation software* koji će biti besplatan za tamošnje vladine urede i policiju iako je sâm projekt navodno vrijedan milijardu američkih dolara. Program će biti upotrijebljen za usporedbu osoba sa slikama unutar baze podataka te za unošenje novih slika, povećavajući tako svakim danom tu bazu podataka. Taj program nove generacije također će, osim lica, moći uspoređivati i ožiljke, tetovaže te ostale oznake na licu i tijelu.

FBI je naglasio da će procijenjenih 12,8 milijuna fotografija iz baze podataka uključivati samo kriminalističke slike osumnjičenih osoba te neće sadržavati ostale fotografije iz ostalih izvora poput društvenih medija.

U budućnosti se nadaju da će u tom programu za svaku pojedinu osobu moći nadodati i identifikaciju šarenica (eng. *Iris identification*), DNK analizu te identifikaciju glasa (eng. *Voice identification*).

Kao što je već prije spomenuto, ovakav softver koristit će se preko kamera postavljenih od strane određene države (poput Velike Britanije), određenog grada (London, Zagreb...) i određenih bitnih lokacija (poput zračnih luka).

9.2. Komercijalna uporaba

BBC vijesti, online portal [13], donose vijest iz 2013. godine kako najveća društvena mreža današnjice *Facebook* kupuje izraelsku tvrtku za prepoznavanje lica *Face.com*. Njihov softver pomaže *Facebook*-u da unesu fotografiju, da prepozna lice na fotografiji, označi ga te nudi svojim korisnicima da jednim brzim klikom mogu identificirati osobu sa slike.

Službeno obrazloženje *Facebook-a* za ovakvo nešto je da „ljudi koji upotrebljavaju *Facebook* uživaju u razmjeni fotografija i uspomena s prijateljima, te je *Face.com* tehnologija koja je pomogla pružiti ljudima najbolje fotografsko iskustvo“.

Prema *Gizmodo.com* internetskom portalu [18], komercijalna uporaba ovakve vrste tehnologija je jako popularna u kasinima diljem svijeta. Naime, neka velika kasina ne mogu sve ručno obavljati pa zato posjeduju računalnu opremu koja im olakšava posao.

Posjeduju nove moderne kamere visoke definicije koje prate svaki korak svojih korisnika. Pametni sustav automatski snima lice te ga uspoređuje s nepoželjnim osobama u bazi podataka kasina. Ako sustav nađe podudarnost, odmah javlja osiguranju koje zatim isprati nepoželjnu osobu iz kasina. Razlika je u tome što nepoželjne osobe mogu biti bivše varalice koje kasina ne žele u svojoj blizini no to ne mora automatski značiti da se zbog njih treba zvati policija.

Kasina također imaju nekoliko novih sustava protiv varanja poput označavanja karata nevidljivom tintom koje prati računalni sustav. Sustav prati mogućnost zamjene karata (eng.

Angel Eye), zatim sustav praćenja čipova koji zamjenjuju novac kao zaštitu od krađe te novi sustav *NORA* koji povezuje ljude u prostoriji odnosno stvara veze među poznanicima koji se također mogu udružiti radi varanja. Neka kasina imaju i softvere za prepoznavanje registarskih tablica. Prije nego što neželjena osoba dođe unutar kasina, ako ima automobil, softver za prepoznavanje registarskih tablica slika registarsku tablicu. Taj softver se temelji na optičkom prepoznavanju znakova koji zatim prepozna znakove i brojeve te ih također uspoređi s bazom podataka.

U komercijalnu uporabu također možemo ubrojiti uporabu ovog softvera u mnogim tvrtkama i njihovim uredima, tj. kao kontrolu zaposlenika prilikom ulaska u zgradu.

10. BAZA PODATAKA

Šimović [4] pojašnjava baze podataka: „Termin baze podataka rabi se u širem i užem značenju. Pod BP-om podrazumijeva se skup podataka o nekomu realnom sustavu kojim se on opisuje. BP je, prema tome, model tog sustava. Kad se opisuju organizacijski sustavi treba imati na umu da se sve u organizaciji ne može formalizirati ili se može formalizirati vrlo neprecizno. Na primjer, motivacija ili iskustvo radnika i sl. su aspekti organizacije koji se ne mogu zanemarivati kad se formira njezin model. U širem značenju BP podrazumijeva način organizacije, čuvanja i pretraživanja uzajamno povezanih podataka namijenjenih informacijskom osiguranju zadataka koji se rješavaju u dijelovima kolektivnog korištenja informacija u procesu funkcioniranja informacijskog sustava. (...)“

Prema užem značenju, baze podataka obuhvaćaju podatke koji su u domeni računalskih sustava. Znači podaci koji su registrirani na magnetnim medijima i po potrebi se mogu unositi u centralni procesor računala i obrađivati, dijelovi su BP-a. (...)“

Prividni koncept BP-a je vrlo jednostavan: jedanput se unesu svi potrebni podatci i uzimaju se oni koji su potrebni i kad su potrebni.“

Prema softveru BetaFace SDK [23], proces prepoznavanja lica uključuje pretvaranje informacija lica i pripadajuće fotografije unutar neovisnog binarnog *ključa* za prepoznavanje koji inače ima veličinu od nekoliko kilobajta ili manje i može biti spremljen u bazi podataka ili bilo kojem sličnom sustavu. Ključ za prepoznavanje su dakle, lice i opisi facijalnih svojstva u kompaktnoj binarnoj formi. Ključevi za prepoznavanje mogu biti uspoređeni u paru dajući vrijednost za sličnost.


Vrijednost za sličnost može biti upotrijebljena ili direktno da razvrsta rezultate usporedbe više različitih lica poredanih po sličnosti ili s pretvorbom za specifične lažne vrijednosti (eng. *false alarm*) po ocjeni poretka, daju normaliziranu samouvjerenu vrijednost – kolika je zapravo mogućnost da dva lica pripadaju istoj osobi, u rangu od 0 do 100% koja također uključuje odluku je li to ista osoba ili nije. Točnost ovakvih zadataka identifikacije/verifikacije jako ovisi o upotrijebljenim podacima, veličini problema, određenom algoritmu i strategiji usporedbe.

Rezultat detekcije je zapravo zbirka metapodataka povezanih sa svakim detektiranim licem. Ova zbirka metapodataka je spremljena u odvojenim unutarnjim zbirkama objekata za svako lice. Unutar te baze možete pretraživati koliko je lica detektirano, vratiti točno određene metapodatke za svako lice te poslije dobiti/namjestiti individualne vrijednosne parametre.

„Osnovna postavka koncepcije tog pristupa jest: svi podatci u jednom informacijskom sustavu integriraju se u jednu fizičku strukturu podataka i svi aplikacijski programi rabe sustavni softver za upravljanje BP-om kojim se preslikava fizička struktura u logičku strukturu kakvu zahtijeva aplikacijski program“, zaključuje Šimović [4].

11. USPOREDBA S OSTALIM SUSTAVIMA

U kontekstu biometrijskog prepoznavanja, Gorodnichy [6] objašnjava kako biometrijski podaci mogu biti kategorizirani prema kvaliteti i dostupnosti (slika 23).



Slika 23. Kvaliteta i dostupnost različitih biometrijskih modaliteta koji su temeljeni na različitim fotografijama (šarenica oka, otisak prsta, lice u dokumentu, lice u videu, hod, boja očiju i kože te visina)

Slika 23 objašnjava pozicioniranje različitih biometrijskih modaliteta prema razini kvalitete i dostupnosti. Prema Gorodnichy [6], ekstremi su prisutni s obje strane ove kategorizacije:

- *prepoznavanje šarenice oka* – vrlo velika prepoznatljivost no vrlo nametljivo,
- *visina osobe ili boja njene kože* – nije toliko diskriminirajuće, ti su podaci prihvatljivi i lako se prikupe,
- *otisci prstiju* – nije lako dostupno, jer zakoni za dobivanje otisaka prstiju osoba su različiti u svakoj državi (u Hrvatskoj je npr. obavezno dati otisak prsta kod dobivanja službenih dokumenata dok u Americi to nije) te također mora biti obavljeno pod kontroliranim uvjetima (samim time je i vrlo limitirana uporaba),
- *slike lica iz videa* – vrlo dostupne, mogu biti preuzete iz daljine i lako pohranjene no najveći njihov problem je kvaliteta u usporedbi s fotografijama.

12. ZAKLJUČAK

Istraživanja usmjerena ka pronalaženju učinkovitih računalnih softvera za prepoznavanje lica i algoritama za takve softvere, temeljena na detekciji lica prema fotografijama, praćenju i prepoznavanju lica te usporedbi s bazom raznih fotografija lica, imaju za cilj pariranje ili čak nadilaženje ljudske sposobnosti prepoznavanja lica. Ona pokazuju da na identifikaciju bitno utječu različiti uvjeti dobivanja slike ljudskih lica, a to su poza (eng. *Pose*), osvjetljenje (eng. *Illumination*) i izraz lica (eng. *Expression*), što prema Chellappa et al. [5] tvori kraticu PIE. Iz objašnjenja u radu razvidno je da su autori Delač i Grgić [2] u pravu kad tvrde da je automatsko prepoznavanje lica kompleksno zbog otežavajućih okolnosti u kojima nastaje fotografija (osvjetljenje i kut fotografiranja mijenjaju se s obzirom na pokrete tijela) i zbog različitih drugih efekata kao što su starenje, izraz lica, različite smetnje itd. Preporuka je istraživačima iz područja računalstva, analize i obrade slike, prepoznavanja uzoraka, strojnog učenja i drugih područja da im polazište za istraživanja bude ljudska sposobnost prepoznavanja ljudi tj. ljudski mozak i oči. Pri izradi algoritma za detekciju lica putem fotografije znanstvenici uzimaju u obzir sve uvjete u kojima je lice snimljeno i sve promjene koje su se na njemu dogodile starenjem ili načinom života. Algoritam Viola – Jones temelji se na tzv. *Haar-like* svojstvima, integralnoj slici i AdaBoost algoritmu za učenje. On je jedan od najučinkovitijih algoritama za traženje lica na postojećoj fotografiji i odvajanje lica od svega ostalog (pozadine) na fotografiji.

Unatoč svim istraživanjima u posljednjih 20 godina, softver i algoritam daleko su još od pravih i konačnih rješenja, jer biometrija koja uključuje prepoznavanje ne samo lica već i otisaka prstiju, šarenice oka, glasa, rukopisa, hoda itd. još uvijek predstavlja izazov za istraživače. Softver ne mora nužno biti povezan s fizičkom tehnologijom, jer i kamere ili fotoaparati mogu biti izrazito loše kvalitete, odnosno mogu dati fotografije niske rezolucije koje čak i visoko kvalitetan softver ne može upotrijebiti u potpunosti. Prepoznavanje lica otežano je zbog utjecaja vanjskih faktora, a to su prirodno starenje, šminkanje, puštanje brkova i brade, plastične operacije te različiti uvjeti pod kojima su snimke ili fotografije nastale (osvjetljenje, rezolucija fotografije, boja i pigmentacija kože, gubitak forme, negativni kontrast slike, sjenčanje lica, facijalne ekspresije itd.). Pozitivne strane prepoznavanja lica preko videa ili *video-based face recognition* (eng. *VFR*) dokazane su gotovo svakodnevnom praktičnom primjenom u pronalaženju osoba sumnjivog identiteta ili kriminalnih namjera i njihova je namjena višestruko dokazana u području zaštite državne sigurnosti, poboljšanja

interakcije između čovjeka i računala te mnogih drugih komercijalnih mogućnosti. Baze podataka moraju biti aktualizirane da bi softver za prepoznavanje lica bio funkcionalan. U usporedbi sa sličnim sustavima, sustav za prepoznavanje lica pokazuje svoju praktičnu primjenu u dostupnosti podataka, jer svi ostali podaci o osobi (šarenica oka, otisak dlana, boja kože, hod itd.) nisu lako dostupni i ne mogu se jednostavno prikupiti pa samim time niti upotrijebiti u šire svrhe.

13. LITERATURA

Knjige:

[1] Delač, K.; Grgić, M.; Bartlett, M.S.; Recent advances in face recognition; In-Teh, ISBN 978-953-7619-34-3; Vienna, Austria, 2008., 236 str.

[2] Delač, K.; Grgić, M.; Face recognition; I-Tech Education and Publishing, ISBN 3-86611-283-1, Vienna, Austria, 2007., 558 str.

[3] Li, S.Z.; Jain, A.K.; Handbook of face recognition; Springer Science and Business Media, Inc., ISBN 0-387-40595-X, United States of America, 2005., 395 str.

[4] Šimović, V.; Uvod u informacijske sustave, 2. dopunjeno i izmijenjeno izdanje, Zagreb, Golden marketing – Tehnička knjiga, Učiteljski fakultet Sveučilišta u Zagrebu, 2010., 462 str.

Članci u časopisima:

[5] Chellappa, R.; Sinha, P.; Phillips, P.J.; „Face Recognition by Computers and Humans,“ IEEE Computer Society, 0018-9162/10 (2010.), str. 46-55.

[6] Gorodnichy, D.; „Video-Based Framework for Face Recognition in Video: Second Workshop on Face Processing in Video“ (FPiV'05) in Proceedings of Second Canadian Conference on Computer and Robot Vision (CRV'05); Victoria, British Columbia, Canada. ISBN 0-7695-2319-6. NRC 48216 (2005.), str. 330-338.

[7] Klontz, J.C.; Jain, A. K.; „A Case Study on Unconstrained Facial Recognition Using the Boston Marathon Bombings Suspects“, Technical Report MSU-CSE-13-4 (2013.), str.1-8.

[8] Sinha, P.; Balas, B.; Ostrovsky, Y.; Russell, R.; „Face Recognition by Humans: Neneteen Results All Computer Vision Researchers Should Know About,“ Proceedings of the IEEE, Vol.94, No.11 (2006.), str. 1948-1962.

[9] Stevanov, Z.; Zdravković, S.; „Prepoznavanje na osnovu pojedinih delova lica“, Psihologija, Vol. 40 (1), (2007.), str. 37-56.

[10] Viola, P.; Jones, M.J.; „Robust Real-Time Face Detection“, International Journal of Kluwer Academic Publishers, The Netherlands, Computer Vision 57(2) (2004.), str.137-154.

Web izvori:

[11] Answers.Ask.com, What is biometrics?

http://answers.ask.com/Computers/Networking_and_Security/what_is_biometrics,

(13. prosinca 2013.)

[12] Argus-Is, Kamera najviše rezolucije, <http://www.youtube.com/watch?v=8zA0Y9SQBBc>,

(9. prosinca 2013.)

[13] BBC vijesti, Facebook kupuje Face.com, [http://www.bbc.co.uk/news/technology-](http://www.bbc.co.uk/news/technology-18506255)

[18506255](http://www.bbc.co.uk/news/technology-18506255), (1. veljače 2014.)

[14] CVDazzle, <http://ahprojects.com/projects/cv-dazzle>, (15. siječnja 2014.)

[15] Ehow.com, Kay Wagers, Face Recognition Software,

http://www.ehow.com/facts_6893646_face-recognition-software_.html, (20. siječnja 2014.)

[16] EndtheLie news, Upotreba softvera za prepoznavanje lica od strane FBI-a,

[http://endthelie.com/2012/08/24/fbi-sharing-facial-recognition-software-with-police-](http://endthelie.com/2012/08/24/fbi-sharing-facial-recognition-software-with-police-departments-across-america/#axzz2r8UMhUuz)

[departments-across-america/#axzz2r8UMhUuz](http://endthelie.com/2012/08/24/fbi-sharing-facial-recognition-software-with-police-departments-across-america/#axzz2r8UMhUuz), (12. siječnja 2014.)

[17] FutureTense blog, ASU, New America, Slate, Upotreba softvera za prepoznavanje lica od strane FBI-a,

http://www.slate.com/blogs/future_tense/2012/08/23/universal_face_workstation_fbi_to_give_facial_recognition_software_to_law_enforcement_.html, (13. siječnja 2014.)

[18] Gizmodo Business and Technology, 7 Kasino tehnologija za koje ne žele da se zna,

<http://www.gizmodo.com.au/2011/08/7-casino-technologies-they-dont-want-you-to-know-about/>, (1. veljače 2014.)

[19] Haar-like features, http://en.wikipedia.org/wiki/Haar-like_features, (16. siječnja 2014.)

[20] New Scientist on-line Magazine/Tech, br.2880, Upotreba softvera za prepoznavanje lica od strane FBI-a, [http://www.newscientist.com/article/mg21528804.200-fbi-launches-1-billion-face-](http://www.newscientist.com/article/mg21528804.200-fbi-launches-1-billion-face-recognition-project.html#UqYdp9JDuSo)

[recognition-project.html#UqYdp9JDuSo](http://www.newscientist.com/article/mg21528804.200-fbi-launches-1-billion-face-recognition-project.html#UqYdp9JDuSo), (12. siječnja 2014.)

[21] Prostorna rezolucija, Procesiranje digitalnih fotografija,

<http://micro.magnet.fsu.edu/primer/java/digitalimaging/processing/spatialresolution/>,

(9. prosinca 2014.)

- [22] Techradar, Kako funkcionira detekcija lica,
<http://www.techradar.com/news/software/applications/how-face-detection-works-703173>,
(10. veljače 2014.)
- [23] Softver za prepoznavanje lica, Betaface SDK, <http://betaface.com/wpa/wp-content/uploads/2014/01/Betaface-SDK.pdf>, (13. veljače 2013.)
- [24] Video na Vimeu, usporena snimka funkcioniranja Viola – Jones algoritma, -
<http://vimeo.com/12774628>, (16. siječnja 2013.)
- [25] Videosurveillance.com, Video nadzor na aerodromima
<http://www.videosurveillance.com/airports.asp>, (13. siječnja 2013.)
- [26] Vimeo, Video o algoritmu Viola – Jones za prepoznavanje lica,
<http://vimeo.com/39561082>, (1. siječnja 2013.)
- [27] W3Schools color picker za HTML, http://www.w3schools.com/tags/ref_colorpicker.asp,
(13. prosinca 2013.)
- [28] Wikipedija, Engleska, Nijanse, <http://en.wikipedia.org/wiki/Hue>, (13. prosinca 2013.)
- [29] Wikipedija, Engleska, Odražavanje, <http://en.wikipedia.org/wiki/Specularity>,
(14. prosinca 2013.)
- [30] Wikipedija, Engleska, Providnost,
http://en.wikipedia.org/wiki/Transparency_and_translucency, (14. prosinca 2013.)
- [31] Wikipedija, Hrvatska, Albedo, <http://hr.wikipedia.org/wiki/Albedo>, (12. prosinca 2013.)
- [32] Youtube, Video s Konferencije o tehnologijama iz 2012.,
http://www.youtube.com/watch?v=q4CrD_zfP08, (7. siječnja 2013.)

Ostalo:

[33] Meduza Rondanini 3D model, vlastiti rad, Lucija Urek -

<https://sketchfab.com/show/5aOC89aBUTCvFkZCLYppPMecIAg>

[34] Vrste prikaza 3D modela, Nastavni materijali predmeta Digitalizacija 3D objekata i prostora, prof. dr. sc. Hrvoje Stančić, Filozofski Fakultet u Zagrebu, 2012.